

Научная статья

УДК 620.178.3

DOI: 10.18577/2307-6046-2024-0-6-80-91

ПРИМЕНЕНИЕ МЕТОДА ГЛУБОКОГО ОБУЧЕНИЯ ПРИ ИССЛЕДОВАНИИ ХАРАКТЕРИСТИК ТРЕЩИНОСТОЙКОСТИ

А.Д. Монахов¹, Н.О. Яковлев¹

¹Федеральное государственное унитарное предприятие «Всероссийский научно-исследовательский институт авиационных материалов» Национального исследовательского центра «Курчатовский институт», Москва, Россия; admin@viam.ru

Аннотация. Представлен алгоритм определения длины и положения усталостной трещины, основанный на применении трехмерной сверточной нейронной сети при проведении испытания на скорость роста трещины. Предложен алгоритм калибровки системы видеофиксации с использованием реперных меток в виде матричных штриховых кодов. Выполнено сравнение результатов применения алгоритма и типовых испытаний. Кинетическая диаграмма разрушения, полученная с использованием нейросетевой модели, характеризуется большим объемом наблюдений, а также меньшим значением дисперсии ошибки аппроксимации результатов измерения.

Ключевые слова: скорость роста трещины усталости, трещиностойкость, машинное зрение, сверточная нейронная сеть, коэффициент интенсивности напряжений, визуальный контроль

Для цитирования: Монахов А.Д., Яковлев Н.О. Применение метода глубокого обучения при исследовании характеристик трещиностойкости // Труды ВИАМ. 2024. № 6 (136). Ст. 08. URL: <http://www.viam-works.ru>. DOI: 10.18577/2307-6046-2024-0-6-80-91.

Scientific article

APPLICATION OF THE DEEP LEARNING METHOD IN STUDYING CRACK RESISTANCE CHARACTERISTICS

A.D. Monakhov¹, N.O. Yakovlev¹

¹Federal State Unitary Enterprise «All-Russian Scientific-Research Institute of Aviation Materials» of National Research Center «Kurchatov Institute», Moscow, Russia; admin@viam.ru

Abstract. The paper presents an algorithm for determining the length and position of a fatigue crack, based on the use of a three-dimensional convolutional neural network when testing for fatigue crack growth rate. An algorithm for calibrating a video recording system using reference marks in the form of matrix bar codes is proposed. The results of using the algorithm were compared with standard tests. Thus, the kinetic diagram of destruction obtained using a neural network model is characterized by a larger volume of observations, as well as a smaller value of the variance of the approximation error of the measurement results.

Keywords: fatigue crack growth rate, crack resistance, machine vision, convolutional neural network, stress intensity factor, visual inspection

For citation: Monakhov A.D., Yakovlev N.O. Application of the deep learning method in studying crack resistance characteristics. *Trudy VIAM*, 2024, no. 6 (136), paper no. 08. Available at: <http://www.viam-works.ru>. DOI: 10.18577/2307-6046-2024-0-6-80-91.

Введение

В соответствии с принципами безопасной повреждаемости материалов и конструкций существует необходимость в исследовании закономерностей возникновения и развития повреждений [1–3]. Одним из наиболее опасных и трудно прогнозируемых дефектов является усталостное повреждение, как правило приводящее к отказу или разрушению конструкции.

Под усталостным разрушением понимают разрушение материала в результате воздействия циклических нагрузок. Характеристики усталости материалов определяют по результатам циклических испытаний, в том числе с контролем длины усталостной трещины [4–6]. Для оценки геометрических параметров усталостных трещин при испытании на скорость их роста применяют различные виды контроля, такие как визуальный, ультразвуковой, вихретоковый, акустический, магнитный, исследование податливости образца и др. В зависимости от типа материала, формы и размера образца, вида напряженно-деформированного состояния, температуры и среды испытания выбирают наиболее подходящий метод контроля. Наиболее распространенным и универсальным способом является визуальный контроль. Однако данный метод характеризуется высокой трудоемкостью ввиду необходимости присутствия оператора на протяжении всего испытания, продолжительность которого может достигать нескольких суток. Таким образом, возникает необходимость в автоматизации процесса контроля усталостной трещины.

При испытаниях на скорость роста трещины усталости (СРТУ) с помощью цифровых микроскопов регистрируют видеоданные распространения трещины на поверхности образца, которые в дальнейшем можно использовать для подтверждения результатов измерения ее длины. Именно эти данные использованы для обучения модели определения положения усталостной трещины.

Существует несколько способов детекции усталостной трещины по изображению поверхности исследуемого объекта. Например, с помощью методов предварительной обработки цифровых изображений на основе алгоритмов Брэдли, Кэнни, Собеля, преобразования Лапласа и др. выделяют контур трещины на контрастных изображениях. Так, в работах [7–10] представлены результаты применения методов обработки изображений для определения трещин в реальном времени на дорожных покрытиях, бетоне и других конструкционных материалах.

Другой способ определения параметров разрушения материала – применение алгоритма корреляции цифровых изображений. Данный метод основан на попеременном сравнении изображений друг с другом в процессе деформирования и требует нанесения на образец специальной спекл-структуры (пятнистой), а также предварительной калибровки измерительной системы [11]. Полученные поля перемещений и деформаций вблизи трещин, как правило, используют для расчета их длин с помощью алгоритмов, характерных для методов обработки цифровых изображений [12–14]. Однако существуют работы, посвященные решению задач механики разрушения для непосредственного расчета коэффициента интенсивности напряжений по полям перемещений вблизи трещины [15–17].

Одним из наиболее распространенных способов сегментации цифровых изображений (определения принадлежности каждого пикселя изображения к тому или иному классу) является использование сверточных нейронных сетей [18–20]. Сверточная нейронная сеть – это специальная архитектура искусственных нейронных сетей, разработанная на основе анализа биологических механизмов зрения. Архитектура использует операцию свертки для извлечения признаков из входных данных, таких как изображение или звук [21]. Применение сверточных нейронных сетей для сегментации и

классификации изображений с трещинами представлено в работах [12, 22, 23], где описаны модели нейронных сетей и результаты их использования, в том числе при испытаниях на СРТУ [22, 23]. Разработаны готовые модели сегментации и классификации цифровых изображений [21–26]. Однако эти модели анализируют относительно большие объекты на изображениях, поэтому их применение для определения небольших трещин может быть неэффективным. Это связано с тем, что начальные этапы испытаний на СРТУ характеризуются невысокой величиной как раскрытия усталостной трещины, так и коэффициента интенсивности напряжений. Соответственно, на этих этапах усталостная трещина и пластическая утяжка в ее вершине не всегда различимы на статичном изображении поверхности образца.

Кроме того, существуют работы, в которых положение и длину трещины определяют с помощью алгоритмов, объединяющих некоторые из описанных методов. Так, работы [13, 14] посвящены выявлению усталостной трещины по полям перемещений и/или деформаций с применением морфологических операций и оператора Собеля. В работе [12] объединены методы корреляции цифровых изображений и глубокого обучения.

В данной работе изложены особенности определения положения и длины трещины усталости с помощью сверточной нейронной сети при испытании на СРТУ. По сравнению с другими описанными методами применение сверточной нейронной сети не требует предварительной пробоподготовки образца, а также нанесения контрастной или пятнистой структуры. Предложен алгоритм калибровки системы видеофиксации с использованием матричных штриховых кодов типа ArUco. Выполнено сравнение кинетических диаграмм разрушения, полученных по результатам испытаний на СРТУ.

Материалы и методы

Геометрические параметры трещины усталости в процессе испытаний на СРТУ определяли с помощью трехмерной сверточной нейронной сети. Такая архитектура нейронной сети позволяет проводить сегментацию усталостной трещины не по одному статичному изображению, а по их серии – пакету последовательно снятых изображений деформируемого образца. Соответственно, изменяющиеся во времени искажения поверхности образца вблизи трещины также сигнализируют о ее наличии и учитываются для определения ее геометрических параметров. Таким образом, использование трехмерной архитектуры способствует повышению индекса истинно положительных срабатываний алгоритма на начальных этапах испытаний на СРТУ.

Разработанная архитектура нейронной сети (рис. 1) имеет 20 скрытых сверточных слоев и является адаптацией архитектур ResNet [24], VGG-16 [25], U-Net [26]. Модель состоит из сужающегося пути, вплоть до девятого скрытого слоя, где укрупняются карты признаков, и расширяющегося пути после десятого скрытого слоя, где увеличивается размерность карт признаков до исходной размерности входных изображений. На каждом этапе укрупнения карт признаков (уменьшения размерности) происходит удвоение каналов, а на каждом этапе увеличения размерности – уменьшение каналов в 2 раза.

Так, на рис. 1 зелеными блоками обозначены входной и выходной слои с применением к выходному слою логистической (сигмоидальной) функции активации, которая показана зеленой стрелкой.

Синими блоками обозначены трехмерные сверточные слои (*Conv3D*) с ядрами свертки $3 \times 3 \times 3$ и страйдом (шагом свертки) 1, оранжевыми блоками – двумерные сверточные слои (*Conv2D*) с ядром свертки 3×3 и страйдом 1. Использование двух и более сверточных слоев с малыми ядрами свертки подряд является распространенной практикой [25, 26], способствует повышению скорости работы и обучения нейронной сети по сравнению с использованием одиночных слоев с большими ядрами свертки. В парах

между слоями синими стрелками обозначены промежуточные связи с применением функции активации ReLU. Поскольку предполагается, что вершина усталостной трещины будет расположена ближе к центру изображения, граничные эффекты, связанные с перекосом весов на краях изображений, не будут влиять на точность результатов определения трещины. Таким образом, необходимость в «полном» дополнении входов сверточных слоев отсутствует. Однако для удобства проектирования нейронной сети использован «одинаковый» режим дополнения (padding – same), в результате которого границы входных изображений дополняются нулями. Таким образом, в процессе свертки размерность карт признаков не изменяется.

После каждой пары слоев на сужающемся пути следует объединяющий по максимуму слой (MaxPooling), в результате чего частота дискретизации пространства признаков уменьшается в 2 раза. Для возвращения к исходным размерам изображения на расширяющемся пути после каждой пары сверточных слоев располагается слой транспонированной свертки, вызывающий повышение частоты дискретизации пространства признаков в 2 раза. Таким образом, в модели нейронной сети использованы пять объединяющих слоев, в результате чего размерность карт признаков уменьшается в 32 раза, а также пять слоев транспонированной свертки, что приводит к восстановлению размерности карт признаков до размерности исходных изображений. После каждого объединяющего и восстанавливающего слоя также следует функция активации ReLU, которая обозначена черными стрелками.

Серыми стрелками показаны альтернативные связи – связи быстрого доступа [24], по которым карты признаков, минуя более «глубокие» слои, попадают на вход к слоям с той же размерностью, что позволяет восстановить утраченные признаки (или не терять их) в процессе обучения между входным и выходным изображениями.

Ключевой особенностью данной архитектуры нейронной сети является использование трехмерных сверточных слоев, а также связей быстрого доступа между трехмерными и двумерными слоями. Соответственно, для их совместного использования четырехмерные карты признаков перестроены в трехмерные следующим образом: размерность типа (N, W, H, C) перестроена в размерность $(W, H, N \times C)$, где N – количество изображений в серии, C – количество каналов, W и H – ширина и высота изображения. Отсутствие в конце нейронной сети полносвязного участка, характерного для сетей классификации изображений, позволяет детектировать усталостную трещину на изображениях с разрешением отличным от разрешения 640×480 .




Рис. 1. Архитектура нейронной сети с использованием трехмерных сверточных слоев. Размерность типа (N, W, H, C) перестроена в размерность $(W, H, N \times C)$, где N – количество изображений в серии, C – количество каналов, W и H – ширина и высота изображения

Обучающий набор данных формировали по результатам видеосъемки стандартных испытаний на СРТУ. Полученные видеофайлы продолжительностью не менее 2 ч разбиты на пять равномерных участков. Первые 20 кадров каждого участка составляют один пакет тренировочного набора. Таким образом, каждый пакет обучающего набора представляет собой серию из 20 последовательно снятых изображений деформированной поверхности образца. Разметку изображений проводили выделением усталостной трещины на первом кадре каждого пакета. В результате сформировано отдельное изображение, на котором пиксели, соответствующие усталостной трещине, имели значение 1, а остальные 0. Размер обучающего набора данных составлял >400 пакетов. Случайным образом из обучающего набора данных сформированы тренировочная и тестовая выборки с количественным соотношением 4:1.

Обучение нейронной сети проводили на тренировочной выборке методом стохастического градиентного спуска на основе адаптивной оценки моментов до достижения 40 эпох обучения. Шаг обучения составлял 0,001, в качестве функции потерь использована функция на основе индекса Жаккара. Распределение целевой метрики в процессе обучения приведено на рис. 2.

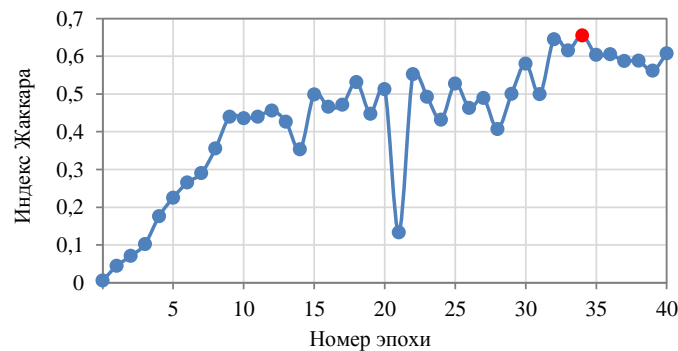


Рис. 2. Распределение целевой метрики в зависимости от номера прохода по тренировочному набору (эпохи)

На рис. 2 видно, что после 34 эпох обучения увеличение количества проходов не способствует повышению целевой метрики. Таким образом, за результат обучения модели приняты наборы весов, которые соответствуют максимальному значению целевой метрики на тестовом наборе данных, т. е. на 34-ой эпохе обучения. Как следует из рис. 3, наибольшая разница между целевыми (рис. 3, б) и предсказанными (рис. 3, в) картами трещин заключается в толщине результата сегментации усталостной трещины, что не влияет на результат определения ее длины.




Рис. 3. Цифровые изображения образцов с трещинами (а), размеченные вручную карты трещин (б) и результат определения усталостной трещины методом глубокого обучения (в)

Для определения физических размеров усталостной трещины по ее цифровым изображениям рассчитывали масштабный коэффициент кадра. Для этого на образец для испытаний вдоль направления роста усталостной трещины предварительно наносили матричные штрихкоды (метки) с закодированными расстояниями от боковой грани каждого штрихкода до оси приложения нагрузки. Определение положения и декодирование меток проводили с помощью модуля ArUco библиотеки компьютерного зрения OpenCV. Метки наносили с помощью лазерного волоконного гравера. Масштабный коэффициент определяли как отношение разницы максимального и минимального значений меток к разнице проекций их положений на горизонтальную ось. Результат применения алгоритма поиска трещины и расчета ее длины в процессе испытания на СРТУ в реальном времени приведен на рис. 4. Длину трещины рассчитывали по формуле

$$l = (q_{\min} - x)\alpha + Q_{\min},$$

где l – длина усталостной трещины, мм; x – проекция положения вершины усталостной трещины на горизонтальную ось, пиксель; $\alpha = (Q_{\max} - Q_{\min}) / (q_{\max} - q_{\min})$ – масштабный коэффициент изображения, мм/пиксель; Q_{\max} и Q_{\min} – максимальное и минимальное значения метки, мм; q_{\max} и q_{\min} – проекции положения метки с максимальным и минимальным значениями на горизонтальную ось, пиксель.

Следует отметить, что необходимо подбирать режим нанесения меток для каждого типа исследуемого материала и предварительно калибровать гравировальный станок. Для повышения вероятности детекции метки наносили как выше, так и ниже области предполагаемого роста трещины, а также таким образом, чтобы в кадр попадало не менее пяти меток вдоль направления роста усталостной трещины. Более простым способом нанесения меток является их печать на самоклеящихся стикерах. При этом особые требования к режиму печати отсутствуют, так как полученные изображения достаточно четкие и контрастные, но появляется необходимость в калибровке принтера.




Рис. 4. Результаты определения усталостной трещины: 1 – контур зафиксированной усталостной трещины; 2 – калибровочные метки

Испытание на СРТУ проводили на образце внецентренного растяжения типа С(Т) из стали системы Fe–Cr–Ni–Co–Mo при частоте нагружения 5 Гц, коэффициенте асимметрии цикла 0,1 и постоянной нагрузке цикла 8 кН. Исходное значение размаха коэффициента интенсивности напряжений составляло $20 \text{ МПа}\sqrt{\text{м}}$. Зависимость зарегистрированных длин усталостной трещины от количества циклов нагружений приведена на рис. 5.

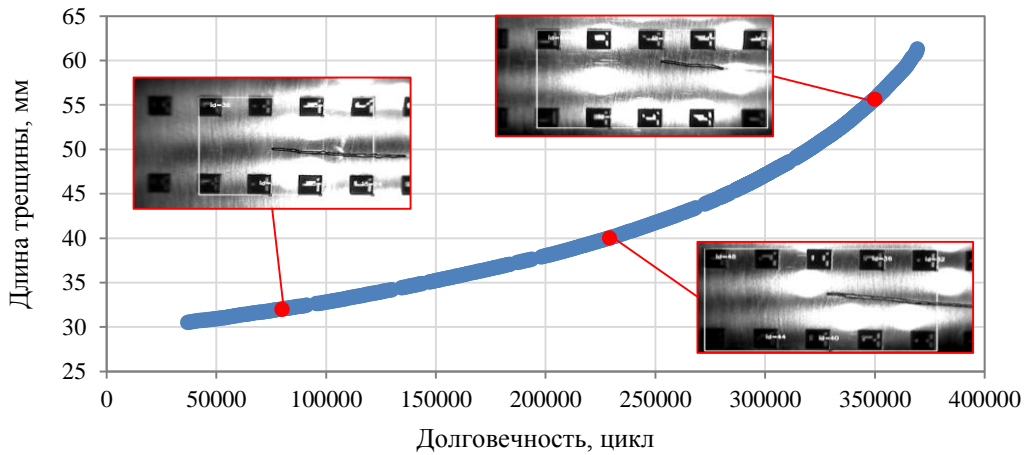


Рис. 5. Диаграмма зависимости длины трещины усталости от количества циклов нагружения

Результаты и обсуждение

Полученные распределения длины трещины в зависимости от количества циклов нагружений пересчитаны в кинетические диаграммы разрушения (КДР) в соответствии с ОСТ 1 92127–90: значения длин усталостной трещины определяли посредством аппроксимации полиномом второй степени экспериментальных значений, представленных на рис. 5, в диапазоне $l_{i-n} \dots l_{i+n}$ ($n = 3$). Значения длин усталостных трещин использованы для расчета их скорости роста и коэффициента интенсивности напряжений. Кинетическую диаграмму разрушения, определенную путем автоматического контроля СРТУ (с применением нейросетевой модели), сопоставили с пятью КДР, полученными по результатам испытаний образцов из того же материала, но при регистрации длины усталостной трещины с помощью визуального контроля (рис. 6).




Рис. 6. Результаты расчета кинетической диаграммы разрушения компактного образца из стали

Диаграммы, полученные методами компьютерного зрения, характеризуются большим объемом данных по сравнению с визуальным контролем, так как длина усталостной трещины регистрируется непрерывно в процессе испытания.

Сходимость КДР оценивали по результатам проверки гипотезы о равенстве регрессий [27]. Рассчитаны параметры разрушения m и C по модели Пэриса, определены

суммы квадратов логарифмов ошибок SSE с количеством наблюдений n в каждой серии, а также дисперсия логарифма ошибки аппроксимации D . Аналогичный анализ проведен по данным, объединяющим все шесть серий. Результаты расчета представлены в таблице.

Параметры разрушения при испытании на скорость роста трещины усталости образца из стали

Метод контроля	Параметры разрушения		Суммы квадратов логарифмов ошибок SSE	Количество наблюдений n	Дисперсия логарифма ошибки аппроксимации D	
	m	C				
Визуальный	1	2,734	-4,765	0,125	44	0,0029
	2	3,367	-5,688	0,058	44	0,0014
	3	2,422	-4,335	0,034	46	0,0008
	4	2,154	-3,939	0,065	45	0,0015
	5	3,071	-5,180	0,086	44	0,0020
Автоматический	2,317	-4,172	0,297	384	0,0008	
Объединенная серия	2,488	-4,410	1,505	607	0,0011	

Гипотезу о равенстве k серий регрессий проверяли с помощью F -критерия Фишера. Если F больше, чем 95 % квантиля F -распределения, то гипотеза о равенстве регрессий отвергается, F рассчитывали по соотношению [27]

$$F = \frac{SSE(R) - SSE(F)}{2(k-1)} + \frac{SSE(F)}{n-2k},$$

где $SSE(R)$ – сумма квадратов логарифмов ошибок для объединенной серии; $SSE(F)$ – сумма SSE всех для k серий регрессий.

Результаты проверки гипотезы о равенстве регрессий:

$SSE(F)$	$SSE(R)$	n	k	F	$F_{n-2k}^{2(k-1)}$
0,664	1,505	607	6	0,085	1,830

Поскольку неравенство $F > F_{n-2k}^{2(k-1)}$ не выполняется, то гипотеза о равенстве регрессионных моделей не отвергается.

Заключения

Предложена архитектура нейронной сети, объединяющая как трехмерные, так и двумерные сверточные слои, а также связи быстрого доступа между ними. Применение описанной модели позволяет определить положение усталостной трещины по сериям изображений деформированной поверхности образца, в том числе на начальных этапах испытания на СРТУ.

Описан способ калибровки видеосистемы, основанный на нанесении реперных меток в виде матричных штрихкодов на поверхность образца. Способ позволяет проводить калибровку для каждой серии изображений. Таким образом, существует возможность корректировки положения камер относительно поверхности образца в случае распространения усталостной трещины за поле контроля.

Проведено испытание на СРТУ с применением алгоритма поиска усталостной трещины, по результатам которого построена КДР. Проведено сравнение КДР, полученных с

помощью визуального контроля и алгоритма, основанного на применении сверточной нейронной сети. Показано, что КДР, полученная с помощью автоматического контроля, характеризуется большим объемом наблюдений (384 точек против 44–46) и меньшим значением дисперсии. Представленную нейросетевую модель можно использовать для автоматического контроля положения и длины усталостной трещины при испытаниях на СРТУ.

Работа выполнена с использованием оборудования ЦКП «Климатические испытания» НИЦ «Курчатовский институт» – ВИАМ в рамках реализации комплексного научного направления 2. «Фундаментально-ориентированные исследования, квалификация материалов, неразрушающий контроль» («Стратегические направления развития материалов и технологий их переработки на период до 2030 года»).

Список источников

1. Ерасов В.С., Нужный Г.А., Гриневич А.В. Об оценке повреждаемости металлических материалов методами механических испытаний // Деформация и разрушение материалов. 2015. № 3. С. 42–47.
2. Ерасов В.С., Орешко Е.И., Луценко А.Н. Повреждаемость материалов при статическом растяжении // Авиационные материалы и технологии. 2015. № 4 (37). С. 91–94. DOI: 10.18577/2071-9140-2015-0-4-91-94.
3. Каблов Е.Н., Гриневич А.В., Славин А.В., Кабанов И.В., Громов В.И., Ампилогов А.Ю., Яковлев Н.О., Поляков А.Н., Якушева Н.А. Расчетные характеристики прочности сталей ВКС-9М и 300М // Заводская лаборатория. Диагностика материалов. 2022. Т. 88. № 3. С. 51–60. DOI: 10.26896/1028-6861-2022-88-3-51-60.
4. Каблов Е.Н., Путьрский С.В., Яковлев А.Л., Крохина В.А., Наприенко С.А. Исследование сопротивления усталостному разрушению штамповок из высокопрочного титанового сплава BT22M, изготовленных с заключительной деформацией в ($\alpha+\beta$)- и β -областях // Титан. 2021. № 1 (70). С. 26–33.
5. Ерасов В.С., Орешко Е.И. Испытания на усталость металлических материалов (обзор). Часть 1. Основные определения, параметры нагружения, представление результатов испытаний // Авиационные материалы и технологии. 2020. № 4 (61). С. 59–70. DOI: 10.18577/2071-9140-2020-0-4-59-70.
6. Митраков О.В., Яковлев Н.О., Якушева Н.А., Гриневич А.В. Особенности разрушения стали 20ХГСН2МФА-ВД при испытании на вязкость разрушения // Авиационные материалы и технологии. 2019. № 1 (54). С. 49–56. DOI: 10.18577/2071-9140-2019-0-1-49-56.
7. Chen C., Seo H., Jun C.H., Zhao Y. A potential crack region method to detect crack using image processing of multiple thresholding // Signal, Image and Video Processing. 2022. Vol. 16. No. 6. P. 1673–1681.
8. Abdel-Qader I., Abudayyeh O., Kelly M.E. Analysis of edge-detection techniques for crack identification in bridges // Journal of Computing in Civil Engineering. 2003. Vol. 17 (4). P. 255–263.
9. Gao H.L., Shen S.S., Yun Y. Fatigue crack length real time measurement method based on camera automatically tracking and positioning // Applied Mechanics and Materials. 2012. Vol. 130. P. 3111–3118.
10. Sun H., Liu Q., Fang L. Research on fatigue crack growth detection of M (T) specimen based on image processing technology // Journal of Failure Analysis and Prevention. 2018. Vol. 18. P. 1010–1016.
11. Монахов А.Д., Гуляев М.М., Гладышева Н.Е., Коптельцева О.Ю., Автаев В.В., Яковлев Н.О., Гулина И.В. Применение метода корреляции цифровых изображений для построения диаграмм деформирования в истинных координатах // Известия высших учебных заведений. Цветная металлургия. 2023. Т. 29. № 3. С. 79–88. DOI: 10.17073/0021-3438-2023-3-79-88.
12. Strohmann T., Starostin-Penner D., Breitbarth E., Requena G. Automatic detection of fatigue crack paths using digital image correlation and convolutional neural networks // Fatigue Fracture of Engineering Materials Structures. 2021. Vol. 44. P. 1336–1348.

13. Orell O., Jokinen J., Kanerva M. Use of DIC in the characterization of mode II crack propagation in adhesive fatigue testing // *International Journal of Adhesion and Adhesives*. 2023. Vol. 122. P. 1–10.
14. Rupil J., Roux S., Hild F., Vincent L. Fatigue microcrack detection with digital image correlation // *The Journal of Strain Analysis for Engineering Design*. 2011. Vol. 46 (6). P. 492–509.
15. Автаев В.В., Яковлев Н.О. Исследование статической трещиностойкости и сопротивления разрушению тонколистового алюминиевого сплава методом корреляции цифровых изображений // *Деформация и разрушение материалов*. 2020. № 2. С. 29–35.
16. Lopez-Crespo P., Shterenlikht A., Patterson E.A. et al. The stress intensity of mixed mode cracks determined by digital image correlation // *Journal Strain Analysis*. 2008. Vol. 43. No. 8. P. 769–780.
17. Du Y., Diaz F.A., Burguete R.L., Patterson E.A. Evaluation using digital image correlation of stress intensity factors in an aerospace panel // *Experimental Mechanics*. 2011. Vol. 51. P. 45–57.
18. Indolia S., Goswami A.K., Mishra S.P., Asopa P. Conceptual understanding of convolutional neural network a deep learning approach // *Procedia Computer Science*. 2018. Vol. 132. P. 679–688.
19. Орешко Е.И., Ерасов В.С., Сibaев И.Г., Луценко А.Н., Шершак П.В. Алгоритмы машинного обучения (обзор). Часть 1. Задачи классификации и регрессии. Линейные алгоритмы в машинном обучении. Применение алгоритмов машинного обучения для расчета прочностных характеристик материалов // *Авиационные материалы и технологии*. 2022. № 3 (68). Ст. 12. URL: <http://www.journal.viam.ru> (дата обращения: 29.02.2024). DOI: 10.18577/2713-0193-2022-0-3-130-146.
20. Орешко Е.И., Ерасов В.С., Сibaев И.Г., Луценко А.Н., Шершак П.В. Алгоритмы машинного обучения (обзор). Часть 2. Метрики машинного обучения. Решающие деревья и ансамбли решающих деревьев. Алгоритм нейронной сети по прогнозированию свойств ферритно-мартенситной стали // *Авиационные материалы и технологии*. 2022. № 4 (69). Ст. 12. URL: <http://www.journal.viam.ru> (дата обращения: 29.02.2024). DOI: 10.18577/2713-0193-2022-0-4-132-146.
21. LeCun Y., Boser B., Denker J.S. et al. Backpropagation Applied to Handwritten Zip Code Recognition // *Neural Computation*. 1989. Vol. 1 (4). P. 541–551.
22. Yingtao Y., Zhendong G., Xin S. et al. Crack Length Measurement Using Convolutional Neural Networks and Image Processing // *Sensors*. 2021. Vol. 21 (17). P. 1–16.
23. Ali R., Chuah J.H., Talip M.S.A. et al. Structural crack detection using deep convolutional neural networks // *Automation in Construction*. 2022. Vol. 133. P. 103989.
24. Kaiming H., Xiangyu Z., Shaoqing R., Jian S. Deep Residual Learning for Image Recognition // *Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, 2016. P. 770–778. DOI: 10.1109/CVPR.2016.90.
25. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // *3rd International Conference on Learning Representations*. San Diego, 2015. P. 1–9.
26. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Munich, 2015. P. 234–241.
27. Расчетные значения характеристик авиационных металлических конструкционных материалов: авиационный справочник в 4 вып. М: ОАК; ЦАГИ, 2012. Вып. 4. 118 с.

References

1. Erasov V.S., Nuzhny G.A., Grinevich A.V. On assessing the damageability of metallic materials using mechanical testing methods. *Deformatsiya i razrushenie materialov*, 2015, no. 3, pp. 42–47.
2. Erasov V.S., Oreshko E.I., Lutsenko A.N. Damageability of materials in tension testing. *Aviacionnye materialy i tehnologii*, 2015, no. 4 (37), pp. 91–94. DOI: 10.18577/2071-9140-2015-0-4-91-94.
3. Kablov E.N., Grinevich A.V., Slavin A.V., Kabanov I.V., Gromov V.I., Ampilogov A.Yu., Yakovlev N.O., Polyakov A.N., Yakusheva N.A. Calculated strength characteristics of steels VKS-9M and 300M. *Zavodskaya laboratoriya. Diagnostika materialov*, 2022, vol. 88, no. 3, pp. 51–60. DOI: 10.26896/1028-6861-2022-88-3-51-60.

4. Kablov E.N., Putyrsky S.V., Yakovlev A.L., Krokhina V.A., Naprienko S.A. Study of resistance to fatigue fracture of forgings made of high-strength titanium alloy VT22M, manufactured with final deformation in the ($\alpha + \beta$)- and β -regions. *Titan*, 2021, no. 1 (70), pp. 26–33.
5. Erasov V.S., Oreshko E.I. Fatigue tests of metal materials (review). Part 1. Main definitions, loading parameters, representation of results of tests. *Aviacionnye materialy i tehnologii*, 2020, no. 4 (61), pp. 59–70. DOI: 10.18577/2071-9140-2020-0-4-59-70.
6. Mitakov O.V., Yakovlev N.O., Yakusheva N.A., Grinevich A.V. Destruction features of steel 20ХГСН2МФА-ВД during the fracture toughness test. *Aviacionnye materialy i tehnologii*, 2019, no. 1 (54), pp. 49–56. DOI: 10.18577/2071-9140-2019-0-1-49-56.
7. Chen C., Seo H., Jun C.H., Zhao Y. A potential crack region method to detect crack using image processing of multiple thresholding. *Signal, Image and Video Processing*, 2022, vol. 16, no. 6, pp. 1673–1681.
8. Abdel-Qader I., Abudayyeh O., Kelly M.E. Analysis of edge-detection techniques for crack identification in bridges. *Journal of Computing in Civil Engineering*. 2003, vol. 17 (4), pp. 255–263.
9. Gao H.L., Shen S.S., Yun Y. Fatigue crack length real time measurement method based on camera automatically tracking and positioning. *Applied Mechanics and Materials*, 2012, vol. 130, pp. 3111–3118.
10. Sun H., Liu Q., Fang L. Research on fatigue crack growth detection of M (T) specimen based on image processing technology. *Journal of Failure Analysis and Prevention*, 2018, vol. 18, pp. 1010–1016.
11. Monakhov A.D., Gulyaev M.M., Gladysheva N.E., Kopteltseva O.Yu., Avtaev V.V., Yakovlev N.O., Gulina I.V. Application of the digital image correlation method for constructing deformation diagrams in true coordinates. *Izvestiya vysshikh uchebnykh zavedeniy. Tsvetnaya metallurgiya*, 2023, vol. 29, no. 3, pp. 79–88. DOI: 10.17073/0021-3438-2023-3-79-88.
12. Strohmam T., Starostin-Penner D., Breitbarth E., Requena G. Automatic detection of fatigue crack paths using digital image correlation and convolutional neural networks. *Fatigue Fracture of Engineering Materials Structures*, 2021, vol. 44, pp. 1336–1348.
13. Orell O., Jokinen J., Kanerva M. Use of DIC in the characterization of mode II crack propagation in adhesive fatigue testing. *International Journal of Adhesion and Adhesives*. 2023, vol. 122, pp. 1–10.
14. Rupil J., Roux S., Hild F., Vincent L. Fatigue microcrack detection with digital image correlation. *The Journal of Strain Analysis for Engineering Design*, 2011, vol. 46 (6), pp. 492–509.
15. Avtaev V.V., Yakovlev N.O. Study of static crack resistance and fracture resistance of thin-sheet aluminum alloy using digital image correlation. *Deformatsiya i razrusheniye materialov*, 2020, no. 2, pp. 29–35.
16. Lopez-Crespo P., Shterenlikht A., Patterson E.A. et al. The stress intensity of mixed mode cracks determined by digital image correlation. *Journal Strain Analysis*, 2008, vol. 43, no. 8, pp. 769–780.
17. Du Y., Diaz F.A., Burguete R.L., Patterson E.A. Evaluation using digital image correlation of stress intensity factors in an aerospace panel. *Experimental Mechanics*, 2011, vol. 51, pp. 45–57.
18. Indolia S., Goswami A.K., Mishra S.P., Asopa P. Conceptual understanding of convolutional neural network a deep learning approach. *Procedia Computer Science*, 2018, vol. 132, pp. 679–688.
19. Butakov V.V., Lugovoy A.A., Varrik N.M., Babashov V.G. Assessment of thermal conductivity of a layered highly porous thermal insulation material. *Aviation materials and technologies*, 2022, no. 3 (68), paper no. 11. Available at: <http://www.journal.viam.ru> (accessed: February 29, 2024). DOI: 10.18577/2713-0193-2022-0-1-129-142.
20. Oreshko E.I., Erasov V.S., Sibayev I.G., Lutsenko A.N., Shershak P.V. Machine learning algorithms (review). Part 2. Machine learning metrics. Decision trees and ensembles of decision trees. An algorithm for neural network to forecast properties of ferrite-martensite steel. *Aviation materials and technologies*, 2022, no. 4 (69), paper no. 12. Available at: <http://www.journal.viam.ru> (accessed: February 29, 2024). DOI: 10.18577/2713-0193-2022-0-4-132-146.
21. LeCun Y., Boser B., Denker J.S. et al. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1989, vol. 1 (4), pp. 541–551.

22. Yingtao Y., Zhendong G., Xin S. et al. Crack Length Measurement Using Convolutional Neural Networks and Image Processing. *Sensors*, 2021, vol. 21 (17), pp. 1–16.
23. Ali R., Chuah J.H., Talip M.S.A. et al. Structural crack detection using deep convolutional neural networks. *Automation in Construction*, 2022, vol. 133, p. 103989.
24. Kaiming H., Xiangyu Z., Shaoqing R., Jian S. Deep Residual Learning for Image Recognition. *Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, 2016, pp. 770–778. DOI: 10.1109/CVPR.2016.90.
25. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations*. San Diego, 2015, pp. 1–9.
26. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Munich, 2015, pp. 234–241.
27. *Calculated values of characteristics of aviation metal structural materials: aviation reference book in 4 issues*. Moscow: UAC; TsAGI, 2012, is. 4, 118 p.

Информация об авторах

Монахов Антон Дмитриевич, инженер, НИЦ «Курчатовский институт» – ВИАМ, admin@viam.ru

Яковлев Николай Олегович, начальник лаборатории, к.т.н., НИЦ «Курчатовский институт» – ВИАМ, admin@viam.ru

Information about the authors

Anton D. Monakhov, Engineer, NRC «Kurchatov Institute» – VIAM, admin@viam.ru

Nikolay O. Yakovlev, Head of Laboratory, Candidate of Sciences (Tech.), NRC «Kurchatov Institute» – VIAM, admin@viam.ru

Статья поступила в редакцию 21.03.2024; одобрена и принята к публикации после рецензирования 09.04.2024.
The article was submitted 21.03.2024; approved and accepted for publication after reviewing 09.04.2024.